



*Patrones de comportamiento de temperatura en el Ecuador en modelos de  
circulación atmosférica mediante Clustering*

*Patterns of temperature behavior in Ecuador in atmospheric circulation models  
through Clustering*

*Padrões de comportamento da temperatura no Equador em modelos de  
circulação atmosférica através de Clustering*

Natalia Alexandra Pérez-Londo <sup>I</sup>  
[nperez@esPOCH.edu.ec](mailto:nperez@esPOCH.edu.ec)  
<https://orcid.org/0000-0001-9068-8790>

Darwin Saul Lema-Londo <sup>II</sup>  
[darwinlema@hotmail.es](mailto:darwinlema@hotmail.es)  
<https://orcid.org/0009-0002-7404-5052>

Erika Alexandra Toapanta-Yugcha <sup>III</sup>  
[erikaalexat21@gmail.com](mailto:erikaalexat21@gmail.com)  
<https://orcid.org/0009-0000-2153-3330>

**Correspondencia:** [nperez@esPOCH.edu.ec](mailto:nperez@esPOCH.edu.ec)

Ciencias Técnica y Aplicadas  
Artículo de Investigación

\* **Recibido:** 30 de junio de 2023 \* **Aceptado:** 17 de julio de 2023 \* **Publicado:** 21 de agosto de 2023

- I. Máster Universitario en Estadística Aplicada, Docente ocasional en Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.
- II. Ingeniero Mecánico, Investigador Independiente, Riobamba, Ecuador.
- III. Ingeniera en Estadística Informática, Investigadora Independiente, Riobamba, Ecuador.

## Resumen

La circulación atmosférica, influenciada por la radiación solar y las temperaturas, regula la distribución de calor, humedad y energía en la Tierra, impactando los patrones climáticos. Su análisis estadístico es crucial para identificar tendencias y fenómenos climáticos extremos como inundaciones o sequías, mejorando las predicciones meteorológicas y el entendimiento del cambio climático. Esta investigación tuvo como objetivo conocer el comportamiento de los patrones de temperatura en el Ecuador, utilizando técnicas estadísticas y de aprendizaje no supervisado mediante la agrupación de características similares. El estudio es de tipo cuantitativo y analiza los patrones de temperatura en Ecuador de 2020 a 2050 utilizando datos de predicción del clima. Se emplearon técnicas de reducción de dimensionalidad (PCA, TSNE y UMAP) y algoritmos de agrupamiento (K-means, DBSCAN, Agglomerative Clustering) para identificar comportamientos similares en los datos. Se evaluó la confiabilidad mediante el coeficiente de Silhouette y se validaron los resultados con diferentes métricas y gráficas usando Python como lenguaje de programación. En los resultados se implementó el algoritmo UMAP para reducir la dimensionalidad con 20 vecinos y distancias calculadas mediante Chebyshev, logrando el mejor modelo de clustering en K-means con 4 grupos y un índice de Silhouette del 67%, que fue el más destacado. Se concluyó que cuatro grupos identificados podrían asociarse con frecuencias de días con temperaturas altas, muy altas, bajas y normales, lo cual coincide con los resultados del análisis exploratorio.

**Palabras clave:** Circulación atmosférica; comportamiento climático; K-means; Modelo de Clustering.

## Abstract

Atmospheric circulation, influenced by solar radiation and temperatures, regulates the distribution of heat, moisture, and energy on Earth, impacting weather patterns. Its statistical analysis is crucial to identify trends and extreme weather events such as floods or droughts, improving weather predictions and understanding of climate change. This research aimed to know the behavior of temperature patterns in Ecuador, using statistical techniques and unsupervised learning through the grouping of similar characteristics. The study is quantitative and analyzes the temperature patterns in Ecuador from 2020 to 2050 using climate prediction

data. Dimensionality reduction techniques (PCA, TSNE, and UMAP) and clustering algorithms (K-means, DBSCAN, Agglomerative Clustering) were used to identify similar behaviors in the data. Reliability was evaluated using the Silhouette coefficient and the results were validated with different metrics and graphs using Python as the programming language. In the results, the UMAP algorithm was implemented to reduce the dimensionality with 20 neighbors and distances calculated using Chebyshev, achieving the best clustering model in K-means with 4 groups and a Silhouette index of 67%, which was the most outstanding. It was concluded that four identified groups could be associated with frequencies of days with high, very high, low and normal temperatures, which coincides with the results of the exploratory analysis.

**Keywords:** Atmospheric circulation; climatic behaviour; K-means; Clustering model.

## Resumo

A circulação atmosférica, influenciada pela radiação solar e pelas temperaturas, regula a distribuição de calor, umidade e energia na Terra, impactando os padrões climáticos. A sua análise estatística é crucial para identificar tendências e eventos meteorológicos extremos, como cheias ou secas, melhorando as previsões meteorológicas e a compreensão das alterações climáticas. Esta pesquisa teve como objetivo conhecer o comportamento dos padrões de temperatura no Equador, usando técnicas estatísticas e aprendizado não supervisionado por meio do agrupamento de características semelhantes. O estudo é quantitativo e analisa os padrões de temperatura no Equador de 2020 a 2050 usando dados de previsão climática. Técnicas de redução de dimensionalidade (PCA, TSNE e UMAP) e algoritmos de agrupamento (K-means, DBSCAN, Agglomerative Clustering) foram usados para identificar comportamentos semelhantes nos dados. A confiabilidade foi avaliada usando o coeficiente Silhouette e os resultados foram validados com diferentes métricas e gráficos usando Python como linguagem de programação. Nos resultados, o algoritmo UMAP foi implementado para reduzir a dimensionalidade com 20 vizinhos e distâncias calculadas usando Chebyshev, obtendo o melhor modelo de agrupamento em K-means com 4 grupos e um índice Silhouette de 67%, que foi o mais destacado. Concluiu-se que quatro grupos identificados podem estar associados a frequências de dias com temperatura alta, muito alta, baixa e normal, o que coincide com os resultados da análise exploratória.

**Palavras-chave:** Circulação atmosférica; comportamento climático; K-meios; Modelo de agrupamento.

## Introducción

En los últimos años, el planeta Tierra ha experimentado un aumento en su temperatura debido a los gases de efecto invernadero. Estos gases provienen de diversas actividades humanas, como la industria, los desechos y los incendios. Esta situación ha generado variaciones climáticas que afectan el equilibrio establecido en los patrones de temperatura, precipitaciones y movimientos atmosféricos en diferentes regiones. Estos cambios climáticos han causado alteraciones en los ecosistemas y la vida en general, lo que requiere una atención urgente para mitigar sus efectos negativos. Los fenómenos meteorológicos y climáticos extremos afectan a la sociedad en áreas como agricultura, infraestructura, salud pública y economía. Entre las consecuencias de este cambio climático se encuentran inundaciones, sequías, huracanes más intensos y el aumento del nivel del mar (Córdova, 2020).

Zorita (2018) manifiesta que numerosos eventos climáticos extremos están asociados con una circulación atmosférica inusual o atípica. La circulación atmosférica engloba el complejo y extenso desplazamiento de los vientos a nivel mundial, los cuales se encuentran estrechamente vinculados a los patrones de celdas de Hadley, Ferrel y polares. Estas corrientes de aire se originan como resultado de las notables discrepancias en las temperaturas y presiones presentes en la superficie terrestre, siendo consecuencia directa del calentamiento que el globo terráqueo experimenta debido a la radiación solar (Molina et al., 2017).

Cuando los rayos solares alcanzan la Tierra, diferentes regiones reciben cantidades variables de energía solar, lo que da lugar a zonas con temperaturas más elevadas y otras más frescas. Estas diferencias térmicas crean contrastes en la presión atmosférica, propiciando así el desplazamiento del aire en forma de vientos que buscan equilibrar estos gradientes. La circulación atmosférica desempeña un papel fundamental en la distribución del calor y la humedad a lo largo del planeta, influyendo en los patrones climáticos y en la formación de sistemas meteorológicos como huracanes y tormentas.

Las variaciones climáticas a causa de la circulación atmosférica pueden ser detectadas, a través de análisis estadísticos que revelan modificaciones en la media y/o la variabilidad de sus características. Este fenómeno perdura a lo largo de un período prolongado, típicamente de décadas o incluso más (Salas & Maldonado, 2019). Por lo que preverlos con mayor anticipación

y precisión permite tomar medidas preventivas y de mitigación, implementar planes de contingencia y alertas tempranas para proteger a la población y los recursos.

Domínguez (2018) manifiesta que la información sobre las variables climáticas es predictiva y puede ser de gran utilidad para los tomadores de decisiones en sectores como la agricultura, la planificación del uso del agua, la demanda eléctrica, las estrategias de inversión y la adaptación, entre otros. Además, la predicción más certera facilita decisiones informadas en la gestión de riesgos y fortalece la resiliencia ante desafíos climáticos, favoreciendo un enfoque proactivo en la protección del medio ambiente y el bienestar humano (Collazo, 2018).

Los métodos estadísticos y los modelos de aprendizaje no supervisado permiten identificar grupos con características similares, ya sea con información bivariante e incluso multivariante, en donde se desconoce completamente lo que se busca (García & Molina, 2018), simplemente por medio de fórmulas y algoritmos se agrupa la información de cada grupo que tenga alguna relación o sean semejantes para así poder categorizarlo de alguna forma mediante distancias.

Los métodos de agrupamiento jerárquicos construyen estructuras en forma de árbol, o llamadas dendrogramas, así mismo los elementos se agrupan o separan para minimizar una medida de distancia o maximizar una medida de similitud. Existen dos enfoques principales para clasificar estos métodos de agrupamiento: Aglomerativos y Disociativos. En el enfoque Aglomerativo, se inicia con la mayor cantidad de clústeres como elementos existentes y se van fusionando gradualmente en subconjuntos más grandes hasta converger en un único clúster. En cambio, en el enfoque Disociativo, se comienza con un único clúster que abarca todos los elementos y se procede a dividirlo en subconjuntos más pequeños sucesivamente. (Aguilera, et al., 2019).

Los clústeres que surgen durante el análisis definen un grupo de objetos que comparten similitud en un cierto grado, pero difieren de los objetos de otros clústeres, razón por la cual el agrupamiento también es denominado a veces clasificación sin supervisión. El agrupamiento es una excelente técnica para estructurar información y derivar relaciones significativas de los datos (Mirjalili & Raschka, 2017).

K-means es una técnica de agrupamiento particional simple basada en prototipos que intenta encontrar los agrupamientos K especificados por el usuario. Estos grupos están representados por sus centroides que pueden ser la media aritmética o la moda de los objetos de datos en un cierto grupo según se especifique sus atributos de manera numérica o simbólica, así mismo en base a diferentes funciones de distancias pueden conducir a diferentes tipos de K-medias (Wu, 2012).

Durante los últimos años, se ha producido un notable progreso en la aplicación de modelos estadísticos para simular las condiciones climáticas actuales y futuras. Sin embargo, aunque estos modelos son una herramienta valiosa para estimar el comportamiento climático venidero, es esencial tener en cuenta que no tienen la capacidad de cambiar el clima o predecir con precisión desastres naturales (Da Rocha et al., 2017).

Crippa, et al. (2019) menciona que el Ecuador a pesar de ser un país pequeño que no emite tanto CO<sub>2</sub> a la atmósfera como los países industrializados, es el país que emite más gases contaminantes a la atmósfera que otros países Latino Americanos como Paraguay, Bolivia, El Salvador. Esto puede traer importantes consecuencias en el clima del país, como sequías más prolongadas, lluvias más intensas e incremento en la frecuencia e intensidad de eventos climáticos extremos y a consecuencia problemas en la agricultura y la población en general.

La falta de estudios relacionados a los patrones de comportamiento de temperatura incita a investigar el clima en el Ecuador donde contribuyan a la creación de nuevos modelos de predicción, la información será de gran utilidad para la toma de decisiones y eliminar los problemas que se generen por el incremento y disminución de la temperatura, y así mitigar los efectos que alteran los procesos de producción en la agricultura, propagación de enfermedades, fauna y flora. Esta investigación tiene como objetivo conocer los patrones de comportamiento de temperatura en el Ecuador, utilizando técnicas estadísticas y de aprendizaje no supervisado mediante la agrupación de características similares.

## Metodología

El enfoque de la investigación fue cuantitativo, el diseño de la investigación fue no experimental debido a que se busca conocer los patrones de comportamiento de la temperatura que se presentará en el transcurso de los años 2020-2050. La investigación utiliza los datos de predicción del clima en el Ecuador mediante modelos de circulación atmosférica, por esta razón es de tipo longitudinal o evolutiva, debido a que se examinó los cambios a través del tiempo en los diferentes puntos estratégicos. El estudio está focalizado en todo el país. Se considera el total de observaciones diarios desde el año 2020 hasta el año 2050 correspondiente al CMIP6 de la Biblioteca de Datos UCSB CHIRTS v2p0 daily global 0p05 prep disponible en <https://iridl.ldeo.columbia.edu>.

Se efectuó la reducción de la dimensionalidad PCA, TSNE y UMAP, posteriormente se utilizó un gráfico de codo para conocer el número de clústeres o grupos con los que se trabajó en el modelo, así mismo la confiabilidad de los algoritmos ha sido evaluada mediante el coeficiente de Silhouette. Se aplicó algoritmos de agrupamiento de datos como K-means, DBSCAN, Agglomerative Clustering con la finalidad de conocer los patrones de comportamiento de temperatura mediante la agrupación de características similares, finalmente, se validó los datos mediante la verificación y aplicación de diferentes métricas y gráficas. Se hizo uso del lenguaje de programación Python para la programación de los algoritmos de reducción de dimensionalidad y Clustering.

## Resultados

La variable temperatura posee tres dimensiones distintas con sus respectivas coordenadas (Tabla 1) definidas por: Y latitud, X longitud y T tiempo, de la misma forma los datos predichos que han sido recolectados en escala diaria. La matriz de información tridimensional (Tabla 2) posee las siguientes dimensiones: Dimensión 1 (10954), Dimensión 2 (22), Dimensión 3 (34).

**Tabla 1.** Tabla de contingencias de la variable Temperatura Tridimensional

Dimensiones (T:10954, X:34, Y:22)					
<b>Coordenadas:</b>					
*Y	(Y) float32	-16.11	-11.91	9.10	13.31
*X	(X) float32	-105.5	-101.2	-61.88	-59.06
*T	(T) datetime64[ns]	2020-01-03T12:00:00		2049-12-29T12:00:00	
<b>Variable de datos</b>					
adif (T, Y, X) float32...>					

Elaborado por: los autores

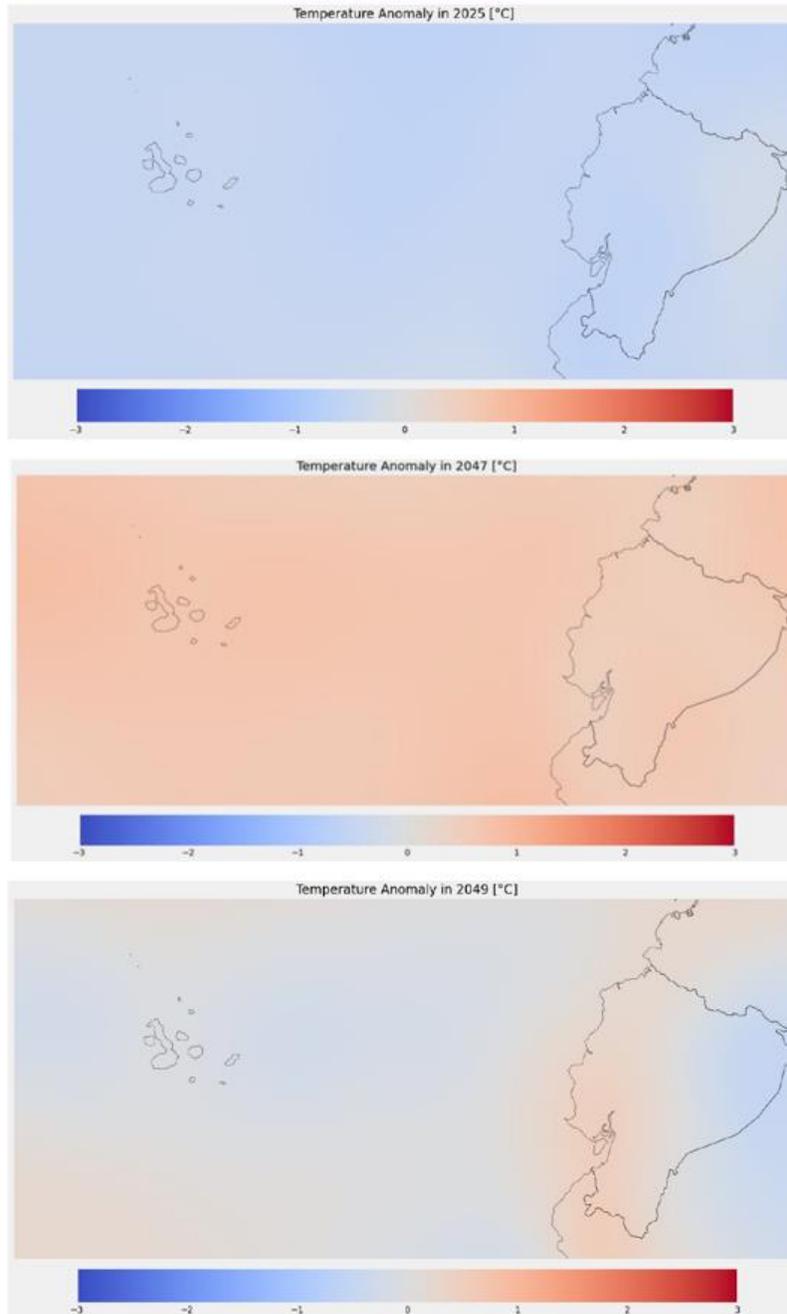
**Tabla 2.** Dimensiones de la matriz tridimensional

	Dimensión 1	Dimensión 2	Dimensión 3
<b>Longitud</b>	10954	22	34

Elaborado por: los autores

Se visualizó el mínimo de temperatura anual por zonas en todo el Ecuador (Figura 1), identificando el cambio que se genera en algunas regiones, entre los cambios más significativos,

se observa que, la temperatura en todo el Ecuador disminuirá en el año 2025, y en el año 2047 la temperatura se intensifica en su totalidad e incluso en el océano Pacífico, sin embargo, en el 2049 la temperatura disminuye en ciertas zonas del Ecuador, manteniéndose una temperatura alta en la región Costa.



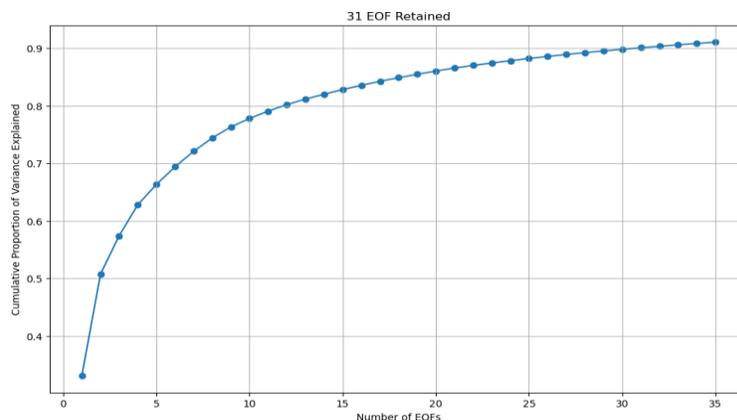
**Figura 1.** Mapas de temperatura mínima para el año 2025, 2047 y 2049.

## Reducción de dimensionalidad

Para la reducción de la dimensionalidad de los datos iniciales, se consideraron las anomalías presentadas. Se observó un promedio cercano a cero, con una desviación estándar de 0.7. Los valores oscilaron entre un mínimo de -1.534 y un máximo de 1.762, mientras que la mediana también se mantuvo cercana a cero. Según el estudio realizado, los datos de temperatura en el Ecuador, en general, mostraron un comportamiento normal, con algunas variaciones, pero siempre dentro de ciertos márgenes y de manera completamente aleatoria. No obstante, se identificó un comportamiento particular en las anomalías, donde en algunos años la temperatura se desvió significativamente. Estas anomalías presentaron una desviación estándar de 0.937, con valores extremos que variaron desde un mínimo de -24.29 hasta un máximo de 7.7871.

El análisis de estas anomalías proporcionó información importante sobre eventos climáticos excepcionales o cambios significativos en el clima, lo que puede tener implicaciones importantes para la comprensión y la predicción de patrones climáticos futuros. La reducción de la dimensionalidad de los datos permitió abordar de manera más eficiente la detección de estas anomalías y la identificación de patrones relevantes en el comportamiento climático del Ecuador.

La matriz bidimensional con los datos apilados para efectuar el Clustering presenta las siguientes dimensiones: Dimensión 1, con una longitud de 10,954, y dimensión 2 con 748 elementos. Con el fin de reducir la dimensionalidad, se aplicó la técnica de Componentes Principales, y se estableció un porcentaje de varianza objetivo del 90%. Para lograr este nivel de varianza, fue necesario conservar un total de 31 componentes, tal como se detalla en la Figura 2.



**Figura 2.** Elección del número de componentes principales

Es importante destacar que, al considerar únicamente los tres primeros componentes, se logra explicar más del 50% de la varianza total de los datos. A partir del quinto componente, el aporte a la varianza se vuelve insignificante. En total, el porcentaje de varianza explicado por estos 31 componentes es de 50.74%, lo que representa un grado significativo de la variabilidad total en los datos. La aplicación de la técnica de Componentes Principales ha permitido reducir la dimensionalidad de manera efectiva, manteniendo una cantidad sustancial de información. Estos resultados son fundamentales para el análisis posterior mediante Clustering, debido a que la reducción de la dimensionalidad facilita la interpretación de los patrones y la identificación de grupos relevantes en los datos. Con este enfoque, se espera obtener una comprensión más clara y concisa de la estructura subyacente en el conjunto de datos y mejorar la eficiencia de los análisis posteriores.

El algoritmo UMAP (Uniform Manifold Approximation and Projection) es un algoritmo de reducción de dimensionalidad no lineal utilizado en el análisis de datos y el aprendizaje automático, en este caso el mismo separa los datos en dos grupos, se procede a etiquetarlos por año, al etiquetar estos puntos se separan los años en términos de temperatura, periodos más cálidos o fríos. Se puede observar en el gráfico de codo (Figura 3) que la selección del número de clústeres es 4, es decir se formaran 4 grupos. La Figura 4 muestra un diagrama de dispersión UMAP con la distancia chebyshev. La Tabla 3 presenta los índices Silhouette para las características UMAP, así también el número de grupos. Es notable observar que la característica que mejor da resultados es al cambiar la medida de distancia de la euclídea a la de Chebyshev, y el algoritmo de agrupación con mayor índice es el de K-means, los demás funcionan casi igual de bien que K-means pero el algoritmo K-means se recomienda usar cuando los grupos tienen una forma más o menos circular, por lo que se selecciona este algoritmo para realizar el cálculo de la exactitud del mismo frente a la agrupación por años.



Figura 3. Gráfica de codo

Tabla 3. Índices de Silhouette

Características UMAP	Algoritmo	Grupos	Silhouette
UMAP con parámetros por default	K-means	3	0.4604
UMAP metric="euclidean"	K-means	3	0.4985
UMAP metric=" chebyshev"	K-means	4	0.6981
UMAP con parámetros por default	DBSCAN	2	0.3824
UMAP metric="euclidean"	DBSCAN	2	0.1814
UMAP metric=" chebyshev"	DBSCAN	4	0.5373
UMAP con parámetros por default	Agglomerative Clustering	3	0.4402
UMAP metric="euclidean"	Agglomerative Clustering	3	0.4652
UMAP metric=" chebyshev"	Agglomerative Clustering	4	0.56164

Elaborado por: los autores

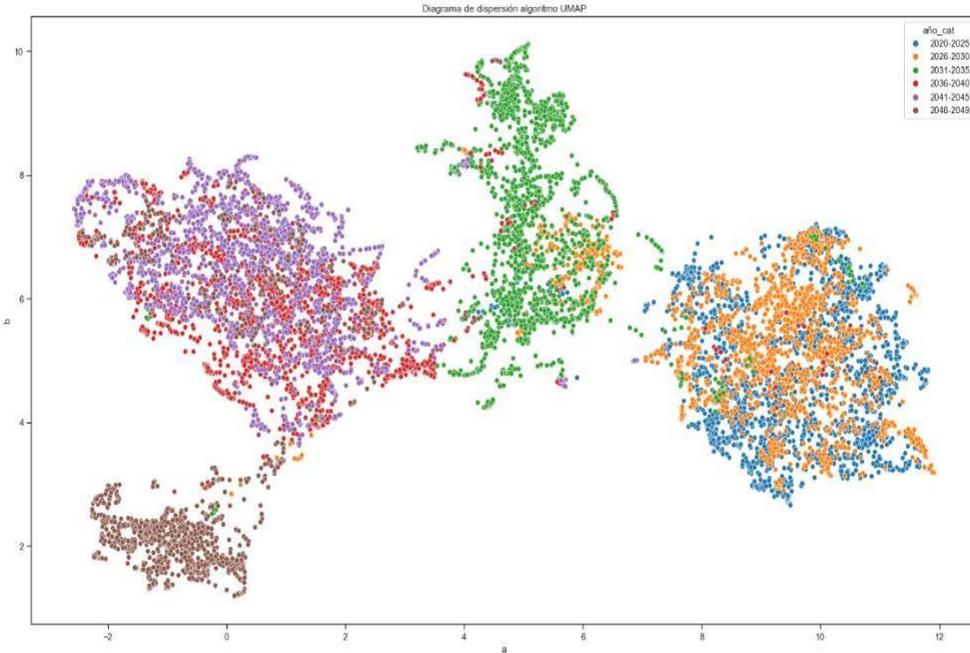


Figura 4. UMAP distancia chebyshev

En la Figura 5, se puede observar que el algoritmo K-means ha realizado una agrupación efectiva debido a que los grupos ya se encuentran bastante separados y tienen una forma aproximadamente circular. Dado este resultado, procedemos a calcular la matriz de confusión para comparar los grupos obtenidos por el algoritmo con los rangos de años a los que pertenecen los datos (ver Tabla 4).

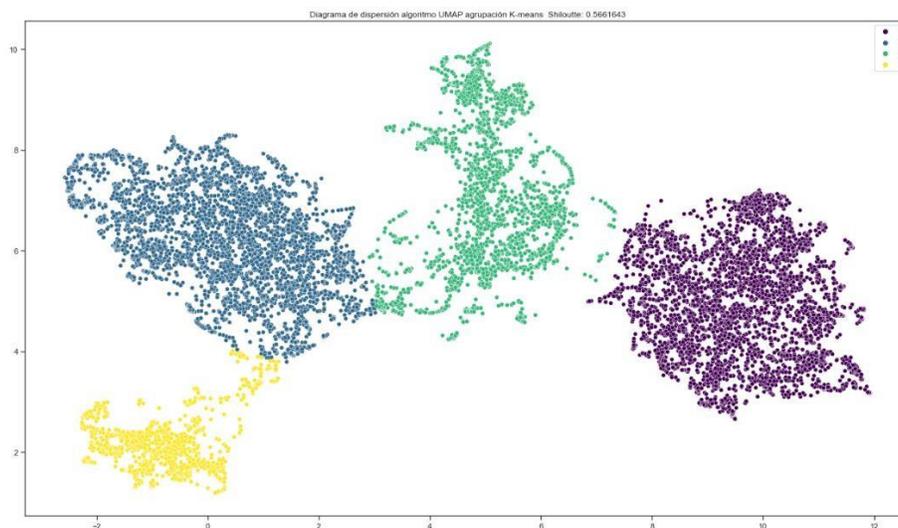


Figura 5. UMAP algoritmo K-means

**Tabla 4.** Rango de años para los grupos

Rango de años	Grupo	Cantidad de observaciones
2020-2030	0	4016
2031-2035	1	3653
2036-2045	2	1826
2046-2049	3	1459

Elaborado por: los autores

La Tabla 5 muestra una matriz de confusión y la exactitud calculada o *accuracy*, se tiene un buen modelo, que permite describir los patrones de comportamiento de la temperatura, en este caso presentó 4 grupos. Hace referencia a los días correctamente agrupados en el rango de años propuestos contrarrestado con los grupos que se forma mediante el algoritmo UMAP-KMEANS. Cabe aclarar en este punto que la matriz de confusión en este caso no se está utilizando con el fin de evaluar el modelo K-means porque estamos en un enfoque de aprendizaje no supervisado, sin embargo se desea mostrar lo que predice K-means versus las categorías que se han encontrado, así, se observar un porcentaje alto de aciertos.

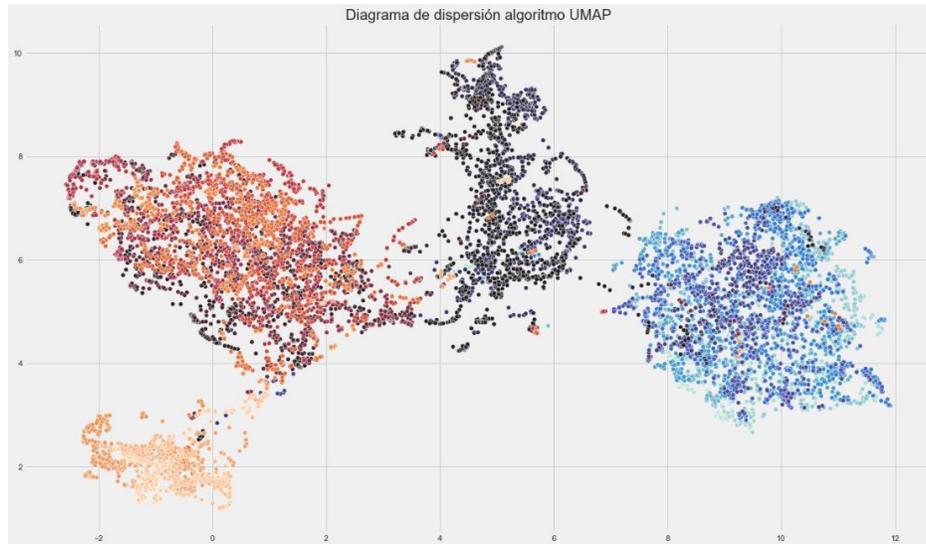
**Tabla 5.** Matriz de confusion

		Valores Reales			
		2020-2030	2031-2035	2036-2045	2046-2049
Valores predichos	2020-2030	3692	9	303	12
	2031-2035	21	3367	224	41
	2036-2045	46	23	1751	6
	2046-2049	12	342	35	1070
Accuracy		<b>0.901953</b>			

Elaborado por: los autores

Con un 90.2% los días están bien clasificados en cada grupo que en este caso son los rangos de años propuestos contrarrestando con los grupos que forman los días mediante el algoritmo UMAP- KMEANS, este resultado indica que en ciertos años ocurre cierto desfase del clima, es decir que los rangos de años que se eligieron se comportan de manera diferente unos de otros

según los 4 grupos que se tiene. Para tratar de explicar esto se representa también el resultado seleccionado de UMAP por día (Figura 6):



**Figura 6.** Diagrama de dispersión UMAP

Los días al igual que los años se encuentran bien distribuidos en los 4 grupos, según avanza el tiempo el color de los días va cambiando y por lo tanto los cuatro grupos muestra temperaturas que se comportan de forma diferente, la causa puede ser desde un fenómeno climático hasta cierta frecuencia de días en los que ocurre este patrón como puede ser: temperaturas bajas, temperaturas altas, temperaturas normales y temperaturas muy altas (Tabla 6).

**Tabla 6.** Rango de años para los grupos.

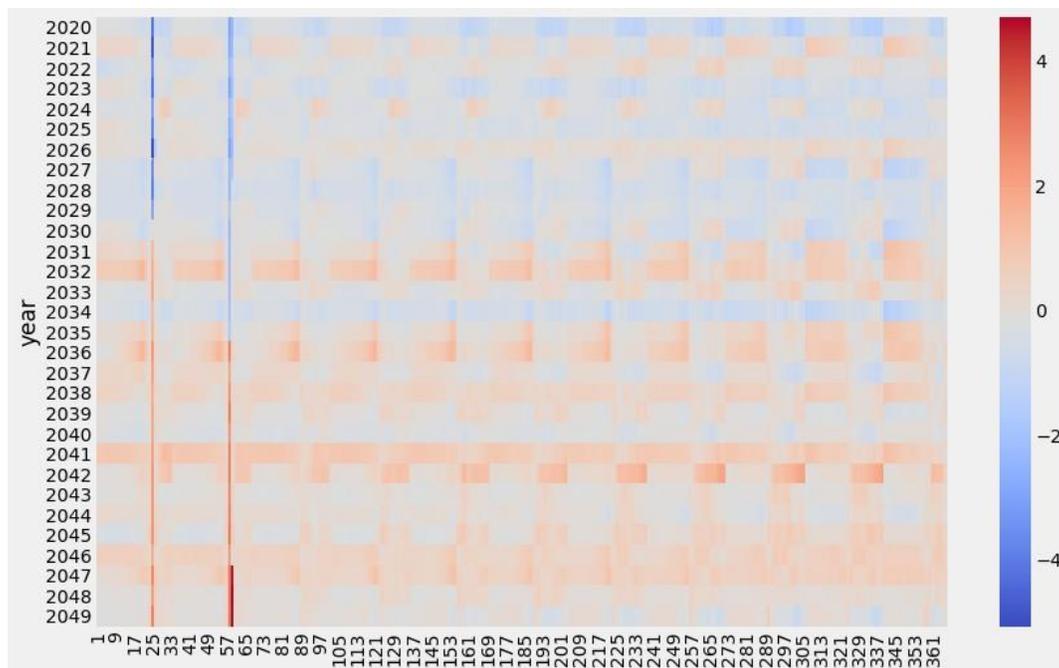
Rango de años	Grupo	Cantidad de observaciones predichas	Frecuencia Relativa	Patrones
2020-2030	0	3771	34.43%	Temperaturas normales
2031-2035	1	3741	34.15%	Temperaturas altas
2036-2045	2	2313	21.12%	Temperaturas bajas
2046-2049	3	1129	10.31%	Temperaturas muy altas

Elaborado por: los autores

Las temperaturas bajas y altas formarían dos grupos 1 y 2, debido a que como se observó en los mapas por lo general el Ecuador tiende a calentarse y disminuir su temperatura muy seguido debido a la cercanía con el océano Pacífico que es un factor importante. Las temperaturas normales corresponden al grupo número 0 que es el más frecuente, se vio en los histogramas de frecuencia que la temperatura con mayor frecuencia se comporta de forma normal.

Las temperaturas anormalmente altas deben pertenecer al grupo 3 que ocurren con menos frecuencia y la tendencia creciente en los gráficos indican que a medida que pase los años el calentamiento global jugará un papel importante en la situación climática, por lo tanto, generarán días con clima anormalmente alto en el Ecuador.

Mediante el gráfico de calor (Figura 7) representado con los 365 días del año simultáneamente desde los años 2020 al 2050 se puede observar que entre los años 2047 al 2050 existirá un incremento en la temperatura, es decir, aproximadamente en el mes de febrero se prevé que el clima tendrá un comportamiento abrupto en dichos años. El cambio climático se evidencia en el 2032 es decir la temperatura aumenta drásticamente, lo que podría generar durante todo el año cuantiosas pérdidas económicas y naturales en todo el Ecuador.



**Figura 7.** Gráfico de Calor representado diariamente respecto a los años

## Conclusiones

Se efectuó un algoritmo de reducción de la dimensionalidad denominado UMAP con número de vecinos igual a 20, y las distancias calculadas con el método de Chebyshev obtenemos el mejor modelo de Clustering en K-means con 4 grupos, y un índice de Silhouette de 67% que resultó el mejor.

Existen algunas posibles explicaciones de lo que ocurre con el comportamiento del clima en todos estos 30 años estudiados a futuro, el primero tiene que ver con el fenómeno del niño el cuál ocurre cada 3 o 7 años en el Ecuador, el último fenómeno del niño ocurrió en 2014 y duró hasta 2016, el próximo podría explicarlo el primer grupo que va desde 2020-2030 y los demás en los siguientes rangos de años de cada grupo, la zona de convergencia intertropical podría explicar también otro fenómeno que hace que el Ecuador en ciertos años se enfríe, otro fenómeno es la oscilación del océano Pacífico el cual ocurre cada 20 o 30 años por lo que no se ajusta al rango de años de los grupos, que son cada 10 o 15 años.

Se concluye que los cuatro grupos encontrados podrían pertenecer a frecuencias de días con temperaturas, altas, muy altas, bajas, y normales, la cuales pueden presentarse en el transcurso de los años en el periodo comprendido entre 2020 al 2049.

## Referencias

1. Aguilera, P., Roper, R. & Schmitz, C., 2019. *Manual de prácticas de conservación y gestión en Espacios Naturales Protegidos*. España: Universidad Almería.  
<https://doi.org/10.1590/0102-778631231420150070>
2. Córdova, H. (2020). Vulnerabilidad y gestión del riesgo de desastres frente al cambio climático en Piura, Perú. *Semestre económico*, 23(54), 85-112.  
<https://doi.org/10.22395/seec.v23n54a5>
3. Collazo, S. M. (2020). *Predicción estacional de extremos climáticos de temperatura en la Argentina* [Tesis Doctoral, Universidad de Buenos Aires].  
[https://bibliotecadigital.exactas.uba.ar/download/tesis/tesis\\_n6733\\_Collazo.pdf](https://bibliotecadigital.exactas.uba.ar/download/tesis/tesis_n6733_Collazo.pdf)
4. Crippa, M., Oreggioni, G. & Guizzardi, D., 2019. *Fossil CO2 and GHG emissions of all world countries*. primera ed. Italia: European Union.

5. Da Rocha, C., Müller, G. V., & Martins, K. (2017). Patrones atmosféricos simulados en el clima presente y futuro asociados al descenso de temperatura en el sudeste de Sudamérica. *Boletín geográfico*, (39), 13-34.
6. Domínguez, D. (2018). *Los ciclones tropicales y la predictibilidad del clima de México* [Tesis de doctorado, Universidad Nacional Autónoma de México].
7. García, J. & Molina, J., 2018. *Ciencia de datos Técnicas analíticas y aprendizaje estadístico*. Primera ed. Bogotá: Altaria S.L.
8. Hidalgo-Proaño, M. (2018). Circulaciones atmosféricas en el Ecuador y su influencia sobre la ciudad de Quito. *CienciAmérica*, 7(1), 22-29.
9. Mirjalili, V. & Raschka, S., 2017. *Python Machine Learning*. Segunda ed. España: Marcombo
10. Molina, M., Sarukhán, J., & Carabias, J. (2017). *El cambio climático: causas, efectos y soluciones*. Fondo de Cultura Económica.
11. Salas, E., & Maldonado, E. (2019). Breve historia de la ciencia del cambio climático y la respuesta política global: un análisis contextual. *KnE Engineering*, 5(2), 717-738.  
<https://doi.org/10.18502/keg.v5i2.6294>
12. Vega, S., Malla, C., & Bejarano, H. (2020). Evidencias del cambio climático en Ecuador. *Revista Científica Agroecosistemas*, 8(1), 72-76.  
<https://aes.ucf.edu.cu/index.php/aes/article/view/388>
13. Wu, J., 2012. *Advances in K-means Clustering: A Data Mining Thinking*. China: Springer Science & Business Media.
14. Zorita, E. (2018). Las causas de los fenómenos extremos. *Revista Tiempo y Clima*, 5(62).  
<https://pub.ame-web.org/index.php/TyC/article/download/1679/1903>